

# DETECCIÓN AUTOMÁTICA DE VEGETACIÓN EN ESTADO DE PLÁNTULA EN IMÁGENES PROCEDENTES DE UN VEHÍCULO AÉREO NO TRIPULADO (UAV): APLICACIÓN PARA LA DISCRIMINACIÓN DE MALAS HIERBAS

Torres-Sánchez J.\* , Peña J.M., Serrano-Pérez Á., López-Granados F.

*Instituto de Agricultura Sostenible (CSIC),  
Apdo. 14004, Córdoba, España.*

*\*jtorres@ias.csic.es*

**Resumen:** Investigaciones recientes han demostrado la capacidad de las imágenes procedentes de vehículos aéreos no tripulados (UAV) para la cartografía de malas hierbas en fase de plántula, entre otros usos. El primer paso para su detección es la discriminación de suelo desnudo y vegetación (malas hierbas + cultivo). Para ello, es necesario definir un método que calcule automáticamente el umbral óptimo del índice de vegetación que facilita su detección. Uno de los métodos de cálculo de umbrales más extendido es el método de Otsu. Se presenta la adaptación de este método a un entorno de análisis de imagen orientado a objetos para su utilización en imágenes UAV de girasol, maíz y trigo tomadas con dos sensores de distinto rango espectral a bordo de un UAV. Se obtuvieron valores de  $R^2$  en torno a 0,7 para la relación entre la vegetación observada y la detectada automáticamente.

**Palabras clave:** Índices de vegetación, sensores remotos, teledetección, multiespectral, segmentación, aplicación localizada de herbicidas.

**Summary:** *Automatic detection of vegetation in early season for weed detection in UAV images.* Recent research has demonstrated the ability of Unmanned Aerial Vehicle (UAV) images for weed mapping in early season. First step is the discrimination between bare soil and vegetation (weeds + crop) throughout the definition of a method for optimal thresholding of the vegetation indices that allows vegetation detection. One of the best known thresholding procedures is the Otsu's method. The adaptation of this method to an Object-based image analysis framework is presented for its application for vegetation detection in UAV images acquired over sunflower, maize and wheat crops.  $R^2$  values about 0.7 were achieved for the regression between observed and automatically detected vegetation.

**Keywords:** Vegetation indices, sensors, remote sensing, multispectral, segmentation, SSWM.

## INTRODUCCIÓN

Investigaciones recientes han demostrado la idoneidad de las imágenes procedentes de vehículos aéreos no tripulados (UAVs, por las siglas en inglés de *Unmanned Aerial Vehicle*) para la detección tanto de especies invasoras como de malas hierbas en cultivos (Peña et al., 2013; Hung et al., 2014), incluso en condiciones difíciles como la fase de plántula, en que la mala hierba y el cultivo son difícilmente diferenciables. La idoneidad de esta tecnología se justifica por diferentes causas: 1) las imágenes pueden ser tomadas con el UAV en el momento en que sea necesario, lo que permite adaptarse muy bien a las condiciones del cultivo; 2) al poder realizarse vuelos a baja altura las imágenes tienen una alta resolución espacial, haciendo posible la detección de las plantas incluso en sus fases más tempranas de crecimiento; y 3) el desarrollo de técnicas de análisis de imagen orientado a objetos (OBIA, por las siglas en inglés de *Object Based Image Analysis*), que posibilitan mediante la agrupación de píxeles en “objetos”, un adecuado manejo de la elevada cantidad de información presente en las imágenes de alta resolución espacial, y una mayor precisión en las clasificaciones que la obtenida usando el análisis basado en píxeles (Blaschke, 2010).

Uno de los primeros pasos para la detección de malas hierbas en estado de plántula mediante el análisis de imágenes UAV es la discriminación de la vegetación (malas hierbas + cultivo), a partir de la cual se discriminan las malas hierbas en pasos posteriores. La detección de la vegetación se realiza mediante el uso de índices de vegetación, que son combinaciones matemáticas de los valores espectrales procedentes de las imágenes. Para separar el suelo de la vegetación es necesario encontrar el valor del índice que discrimina entre las dos clases. Por tanto, para conseguir la total automatización de los algoritmos de clasificación de malas hierbas, es necesario definir un método que calcule automáticamente el umbral, es decir, el valor óptimo del índice para la discriminación entre vegetación y suelo desnudo. Uno de los métodos de cálculo de umbrales más extendido en el análisis de imagen es el método de Otsu (1979). Por tanto, en el presente trabajo se presenta la adaptación de este método a un entorno OBIA para la detección de vegetación en imágenes procedentes de UAV con el objetivo final de discriminar las malas hierbas en cultivos de girasol, maíz y trigo en estado de plántula.

## MATERIAL Y MÉTODOS

### UAV y sensores

El UAV empleado fue un multirrotor MD4-1000, con capacidad para llevar acoplado un sensor de hasta 1,25 kg y una autonomía de vuelo de 45 minutos. Este modelo de despegue y aterrizaje vertical está dotado de un receptor GNSS que le permite volar de manera automática siguiendo una ruta previamente programada por el piloto. El sistema de manejo del UAV incluye una emisora de radiocontrol, una estación base para recepción de datos de telemetría, así como un paquete de software para diseño de rutas, configuración del vehículo e interpretación de la telemetría. A bordo del UAV se instalaron por separado dos sensores para sendas evaluaciones, una cámara convencional Olympus PEN E-PM1 y una cámara multispectral Mini-MCA, con el fin de comprobar la influencia de la altura de vuelo sobre la resolución espacial de las imágenes obtenidas con dichos sensores. La cámara Olympus tiene un sensor de 12 Megapíxeles y registra imágenes en rango visible (canales rojo, verde y azul). La cámara Mini-MCA es un sensor multispectral formado por 6 objetivos o sensores CMOS con una resolución de 1,3 Megapíxeles. Cada uno de los objetivos lleva acoplado un filtro para captar información en un rango de 10 nm en torno a seis longitudes de onda, de manera que se obtienen datos espectrales en las siguientes bandas: azul (450 nm), verde (530 nm), rojo (670 y 700 nm), rojo límite (740 nm) e infrarrojo cercano-NIR (780 nm). De estas seis bandas, tres se usaron para componer imágenes con falso color compuestas por los canales infrarrojo, rojo y verde. Más detalles de la configuración del UAV y los sensores consultar Torres-Sánchez et al. (2013).

### Área de estudio

El ensayo fue realizado en la finca pública dedicada a la investigación "Alameda del Obispo" (Córdoba) en un área de 250 m<sup>2</sup>. Se tomaron imágenes a 30 m de altura con los dos sensores sobre cultivos herbáceos de invierno y verano infestados de manera natural por malas hierbas: girasol, maíz, y trigo. Esta altura resultó en un tamaño de píxel de 1,14 cm para la cámara visible y de 1,63 cm para la multispectral. En el momento de la adquisición de las imágenes (29/01/12 para trigo, y 04/06/12 para girasol y maíz) los cultivos estaban en el estado 1 de la escala BBCH (Meier, 2001). Las diferencias entre sensores, la distancia entre hileras de cultivo (17, 70 y 75 cm para trigo, girasol y maíz, respectivamente) y la diversidad de malas hierbas infestantes (dos monocotiledóneas, *Phalaris* spp y *Lolium rigidum*; y una dicotiledónea, *Convolvulus arvensis*) permitieron la validación del algoritmo dada la variedad de escenarios considerados.

## Funcionamiento del algoritmo

El algoritmo presentado es una adaptación a un entorno OBIA del método de cálculo de umbrales de Otsu. Éste ha sido usado con anterioridad en la discriminación de vegetación en imágenes agrícolas (Guijarro et al., 2011; Torres-Sánchez et al., 2014), pero no en entorno OBIA. Este método de cálculo de umbrales se basa en métodos estadísticos que determinan el valor de referencia que mejor separa dos clases en una imagen. Partiendo de un valor inicial, el método va probando de forma iterativa sucesivos valores para clasificar la imagen calculando para cada uno de ellos la varianza de las dos clases resultantes y un parámetro conocido como *varianza entre clases* que cuantifica cómo de diferentes son. A lo largo de este proceso iterativo se busca el valor umbral que maximice la varianza entre clases a la vez que reduce al mínimo la varianza dentro de las dos clases resultantes. Este proceso iterativo de prueba de valores umbral y cálculo de varianzas se programó en forma de bucle dentro del software eCognition 8.9 (Trimble GeoSpatial, Múnich, Alemania).

## Validación del algoritmo

El algoritmo se utilizó para calcular el valor necesario para clasificar los cultivos en las imágenes tomadas en los tres cultivos utilizando dos índices de vegetación. Los índices utilizados fueron ExG (Ecuación 1) para la cámara visible y NDVI (Ecuación 2) para la cámara multi-espectral, dichos índices en el espectro visible y el infrarrojo han sido ampliamente utilizados en la detección de vegetación (Woebbecke et al., 1995).

$$ExG = 2g - r - b; \text{siendo } g = \frac{G}{R + G + B}; r = \frac{R}{R + G + B}; b = \frac{B}{R + G + B} \quad (1)$$

$$NDVI = \frac{NIR - R}{NIR + R} \quad (2)$$

Antes de aplicar el algoritmo a cada una de las imágenes, éstas fueron segmentadas mediante eCognition ajustando los parámetros para obtener objetos cuya forma y dimensiones se ajustaran a las plantas de girasol, maíz, y trigo. Finalmente se comparó el porcentaje de área cubierto por vegetación detectado por el algoritmo con el porcentaje observado delineando manualmente la vegetación sobre la imagen en 30 zonas de 1 m<sup>2</sup>.

## RESULTADOS Y DISCUSIÓN

La Figura 1 muestra la representación gráfica de la comparación entre la vegetación detectada automáticamente y la observada de manera manual, así como los parámetros definitorios de las regresiones lineales entre dichos valores. Con excepción de la clasificación del maíz en la imagen con infrarrojo y del trigo en la imagen convencional o visible, todos los coeficientes de regresión son  $\geq 0,7$ , llegando a alcanzarse un valor de 0,84 y 0,80 para el girasol en la imagen convencional y la infrarroja respectivamente. Estos resultados son satisfactorios ya que en la mayoría de los casos la discriminación de la vegetación es correcta, si bien  $R^2$  a veces es más bajo por datos anómalos que pueden deberse a fallos en la hilera de siembra. También se constata que incluso en los casos con menor  $R^2$ , el RMSE tiene un valor reducido (10,02 en el mayor caso). El hecho de que los mejores resultados se produzcan en girasol se debe a que la planta es mayor que el trigo y tiene una forma más compacta que el maíz, lo que provoca que la segmentación de imágenes de girasol genere objetos mejor ajustados a la forma de la planta y por tanto más fácil de detectar. La Figura 2 muestra varias ilustraciones de las clasificaciones conseguidas en las imágenes analizadas de los diferentes cultivos.




Figura 1. Relación entre la vegetación observada en la clasificación manual y la detectada por el algoritmo automático de cálculo de umbrales para girasol, maíz y trigo en los dos tipos de imagen. La línea sólida representa la recta de regresión ajustada, la discontinua representa la línea 1:1.




Figura 2. Muestras de la imagen original y la segmentación clasificada usando los umbrales calculados de manera automática por el algoritmo para girasol (a), maíz (b), y trigo (c).

Estos resultados indican que la clasificación automática de vegetación en imágenes aéreas-UAV de cultivos herbáceos se puede llevar a cabo de manera precisa, lo que permite la automatización de otros procesos en los que la discriminación de vegetación sea un paso previo crucial como ocurre con la detección de malas hierbas. Otro hecho que avala la posible integración del método presentado en análisis más complejos es que el proceso de cálculo de umbral se llevó a cabo de manera rápida, tardando en todos los casos salvo en el trigo menos de 1 s en un ordenador convencional. En el caso del trigo en la imagen con infrarrojo el proceso requirió de 33 s debido a que los objetos generados para adaptarse al cultivo eran muy pequeños y por tanto abundantes lo que requiere un incremento del tiempo.

## CONCLUSIONES

El algoritmo desarrollado para la detección automática de vegetación en imágenes de cultivos herbáceos tomadas con UAV permite la total automatización de la clasificación de vegetación de cara a la posterior discriminación de malas hierbas en cultivos herbáceos en estado de plántula. Asimismo ha demostrado ser robusto, fiable y rápido, lo que permite su implementación en los complejos algoritmos que se requieren para detección de malas hierbas en cultivos herbáceos.

## AGRADECIMIENTOS

Este trabajo fue financiado por el proyecto AGL2014-52465-C4-4-R MINECO-FEDER. La investigación de Jorge Torres Sánchez y José Manuel Peña Barragán fue financiada por los programas FPI y Ramón y Cajal, respectivamente.

## BIBLIOGRAFÍA

- BLASCHKE T (2010) Object based image analysis for remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing* 65, 2-16.
- GUIJARRO M, PAJARES G, RIOMOROS I, HERRERA PJ, BURGOS-ARTIZU XP & RIBEIRO A (2011) Automatic segmentation of relevant textures in agricultural images. *Computers and Electronics in Agriculture* 75, 75-83.
- HUNG C, XU Z & SUKKARIEH S (2014) Feature learning based approach for weed classification using high resolution aerial images from a digital camera mounted on a UAV. *Remote Sensing* 6, 12037-12054.
- MEIER U (2001) BBCH Monograph: Growth stages for mono- and dicotyledonous plants. Berlin: *Blackwell Wiss.-Verlag*.
- OTSU N (1979) A Threshold selection method from gray-level histograms. *IEEE Transactions on Systems, Man, and Cybernetics* 9, 62-66.
- PEÑA JM, TORRES-SÁNCHEZ J, DE CASTRO AI, KELLY M & LÓPEZ-GRANADOS F (2013) Weed mapping in early-season maize fields using object-based analysis of Unmanned Aerial Vehicle (UAV) Images. *PLoS ONE* 8, e77151.
- TORRES-SÁNCHEZ J, LÓPEZ-GRANADOS F, DE CASTRO AI & PEÑA-BARRAGÁN JM (2013) Configuration and specifications of an Unmanned Aerial Vehicle (UAV) for early site specific weed management. *PLoS ONE* 8, e58210.
- TORRES-SÁNCHEZ J, PEÑA JM, DE CASTRO AI & LÓPEZ-GRANADOS F (2014) Multi-temporal mapping of the vegetation fraction in early-season wheat fields using images from UAV. *Computers and Electronics in Agriculture* 103, 104-113.
- WOEBBECKE DM, MEYER GE, VON BARGEN K & MORTENSEN DA (1995) Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE* 38, 259-269.